

结合分水岭分割的合成核 SVM 高光谱分类

赵振凯 杨明

(南京师范大学计算机学院, 南京, 210000)

摘要: 高光谱图像丰富的光谱信息使其在目标检测、地物分类等领域都具有重要应用, 分类作为高光谱应用的重要中间步骤引起了广泛关注。高光谱图像空间信息刻画了光谱像素点与近邻关系, 可以较好地弥补单纯使用光谱信息难以解决的同物异谱、同谱异物以及高维小样本等问题。传统预处理方式空间信息的使用是基于固定结构(如方窗)选择空间近邻以计算空间特征辅助分类, 但因窗口大小而影响空间特征质量。为此本文提出了结合分水岭分割的合成核支持向量机(Support vector machine, SVM)高光谱分类, 根据分水岭分割图自适应选择优质的空间近邻, 然后通过合成核 SVM 有效地把空间信息融入到原光谱信息分类中。实验表明, 本文方法更好地利用了空间信息, 实现在少量样本下高光谱图像的快速高精度分类。

关键词: 图像分类; 高光谱图像; 分水岭分割; 空间近邻; 合成核支持向量机

中图分类号: TP751 **文献标志码:** A

Combining Watershed Segmentation with Composite-Kernels for Hyperspectral Image Classification

Zhao Zhenkai, Yang Ming

(College of Computer Science, Nanjing Normal University, Nanjing, 210000, China)

Abstract: Hyperspectral images have been widely used in target detection terrain classification and so on owing to its rich spectral information. Classification, being the fundamental step to further explore the hyperspectral images, attracts wider concern. The spatial information describes the connections between pixels with its spatial neighbors which can help to solve the problems like metameric substance of same spectrum, metameric spectrum of same substance and insufficient labeled samples with a high dimension while the spectral information cannot handle well. The traditional preprocessing uses a structure element to obtain the spatial neighbors and assist the last classification with the extracted spatial features. It is obvious that the structure element matters, however one cannot find a suitable size to meet all demands. For dealing with this, a method combing watershed segmentation with composite-kernels support vector machine (SVM) is proposed. It is the characteristics of over segmentation that we use to get a self-adapting spatial neighbors, containing less dissimilar pixels and being more discriminant for every pixel, then we fuse the spatial features and the spectral through the composite-kernels SVM and give a reliable judge-

ment. Experiments show that the proposed method can make a better use of the spatial information and achieve a high accuracy with limited training samples.

Key words: image classification; hyperspectral image; watershed segmentation; spatial neighbors; composite-kernels SVM

引 言

高光谱遥感图像(Hyperspectral image, HSI)通常是指光谱分辨率在 $10^{-2}\lambda$ (λ 代表波长)数量级范围内的一组光谱图像,一般包括几十个甚至数百个光谱波段。与传统遥感成像(可见光、多光谱等)相比,高光谱遥感能够获得更加丰富的地物光谱信息,对于更加详细的地物分析^[1],如目标检测^[2]、地物分类、污染防治,以及军事侦查领域都具有重要应用。高光谱图像分类,作为许多高光谱数据应用的基础任务,受到人们越来越多的重视。

早期遥感图像的分类主要以光谱特征为主,分类精度较低。近年来,人们逐渐认识到结合空间信息能够改善分类结果,因此吸引了越来越多的关注。高光谱像素点数据之间并不是相互独立无序的光谱特征向量,空间位置相邻的像素点往往属于同一类别,即地物分布的空间平滑特性^[3],因此高光谱的分类通常是光谱信息和空间信息相结合的分类,主要有以下 3 种:空间预处理方式、结合空间信息直接分类方式、空间后处理方式。空间预处理,首先提取空间特征,然后联合光谱特征,训练分类器进行图像分类。像 Camps-Valls 和 Bruzzone 等提出使用基于固定窗提取的空间均值/方差作为空间特征,通过合成核训练支持向量机(Support vector machine, SVM),高光谱分类往往面临特征维数高,训练样本少等问题,即 Hughes 现象^[4],核技巧较好地解决高维小样本问题^[5]。而 Fauvel 等^[6]把图像的拓展形态学特征作为空间特征,结合光谱特征进行图像分类。Gurram 等^[7]通过在映射后的核空间取平均引入空间信息,提出了核空间嵌入的 SVM 分类方法。结合空间信息直接分类,是指在分类判决中直接使用空间信息对每个像素进行类别判定,如 Chen 等提出基于字典的稀疏表示高光谱分类方法,依据空间平滑特性,认为固定窗内的像素点拥有共同的一组基,通过获得的稀疏表示给出可靠类别判断^[8-9],以及后续改进算法等^[10]。Li 等^[11]提出了结合空间邻域信息的 SVM 分类算法(Spatial contextual SVM, SCSVM),先通过 SVM 初步分类后像素点分类标签号构造判别值 r ,其值大小表示像素点与邻域点标签的一致程度,进而构建 SCSVM 模型,在分类时直接给出像素点类别。最后对于空间后处理,其更像是一种修正,首先进行初步分类,然后使用空间信息进行像素点的类别纠正,如 Tarabalka 等^[12]通过 SVM 进行初步分类,再结合 MRF 框架,通过提出适合的能量函数,对像素点进行类别修正。Vincent 等^[13]使用分水岭分割后提取的空间信息,对 SVM 初步分类的结果使用投票法纠正,也取得了较好结果。随后他们又提出基于 Markers 的最小传播森林方法,实验证明其效果优异^[14-17]。

Camps-Valls 等^[18]使用固定窗提取像素点近邻均值信息/方差作为空间特征,联合光谱信息共同分类,取得较好效果。在空间预处理方式下,空间特征的优劣较大程度影响了分类精度,Camps-Valls 等的方法,受制于固定窗大小。当窗口选的过大,容易混杂不同地物,而当窗口过小,空间特征与光谱特征区分性不强。而当待分类像素点位于边界区域,或图像包含一些小的或者复杂结构时,几乎不可能找到一个大小合适的固定窗。为此,本文提出了一种基于分水岭分割选择近邻的合成核 SVM 分类方法,通过获取更好的空间特征改善分类结果。

本文方法首先对高光谱图像进行分水岭分割,通过过分割图自适应选择空间近邻,计算空间特征,最后使用合成核 SVM 方法融合空间特征到原光谱分类中,算法流程图如图 1。空间信息不同阶段的使用保证了分类效果改善,与原有算法相比能够在少量样本下显著提高分类精度,表明了本文算法的有效性和实用性。




图1 本文算法的流程图

Fig. 1 Flowchart of the proposed algorithm

1 高光谱下分水岭分割与合成核分类

1.1 高光谱分水岭分割

图像分割是获取空间信息的有力方法之一,分割后的图像可以得到物体的轮廓信息。如在空间后处理方式中,使用高光谱分割图来纠正粗分类结果,分水岭分割是获取分割图的一种方式。

分水岭分割是一种过分割方法,对于一个二维单波图像中每一个点,计算其梯度值,根据梯度图像将之分为若干个积水盆地,每个盆地都跟图像中对应盆地的极小值点有关,分水岭线代表物体的边缘。过分割的特点表现在即使属于同一地物还是会被分成多个区域。

原始的分水岭分割并不适用高光谱图像,为此提出了多种适用于高光谱图像的梯度计算方法^[13-14]。

(1) 形态学梯度

基本形态学梯度计算,膨胀与腐蚀操作差值。

$$\rho_E(I) = \delta_E(I) - \epsilon_E(I) \quad (1)$$

式中 E 表示结构元素, I 表示图像。

因为高光谱图像有几十或上百光谱段,可以选择所有光谱段计算梯度累加值(Sum bands 方式),也可选择某几个计算梯度累加值。

(2) 彩色形态学梯度

彩色形态学梯度 (Color morphological gradient, CMG) 计算方式如下

$$\nabla_{\chi, d}^{CM}(\mathbf{x}_0) = \max_{i, j \in \chi} \{d(\mathbf{x}_0^i, \mathbf{x}_0^j)\} \quad (2)$$

式(2)中: \mathbf{x}_0 表示中心像素点, χ 表示对应的四邻域或八邻域集合, \mathbf{x}_0 梯度值为近邻中距离最大值。

(3) 鲁棒彩色形态学梯度

鲁棒彩色形态学梯度 (Robust color morphological gradient, RCMG) 由 Evans 和 Liu 为彩色图像提出,研究者拓展其到高光谱图像计算


$$\nabla_{\chi, d}^{RCM}(\mathbf{x}_0) = \max_{i, j \in \square_{\chi-REM_r}} \{\|\mathbf{x}_0^i - \mathbf{x}_0^j\|_2\} \quad (3)$$

式中: REM_r 表示去掉其中 r 对最大值,使其对噪声鲁棒。在本文实验中选取方法 1。梯度计算完成后,可以采用 Vincent 和 Soille 提出的淹没法得到最终的分水岭过分割图^[13]。

图 2 为对应 Indian Pines 数据集的标记模板及分水岭分割图。可以看出分水岭分割图较好地刻画了边界信息,图中大小不同的分割区域保证了本文方法空间近邻的选择。

1.2 合成核高光谱分类

核方法较好地解决了高维小样本问题。基于合成核的 SVM^[18],核 Fisher 判别分析都取得了优异的实验结果。这里首先介绍经典 SVM,然后介绍 3 种常见构造核的方式,最后使用合成核



(a) 标记模板
(a) Ground truth

(b) 分水岭分割图
(b) Watershed segmentation map

图2 标记模板与分水岭分割图

Fig. 2 Ground truth and watershed segmentation map

SVM 融合空间特征与光谱特征。

1.2.1 经典 SVM

定义训练集合 $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, 其中 $\mathbf{x}_i \in \mathbf{R}^d$ 为 d 维的特征向量, 对应 $y_i \in \{1, -1\}$ 为分类标签。核映射 $\Phi(\cdot)$ 将原始特征从低维空间映射到高维再生核 Hilbert 空间, 其对应核函数 $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$ 。为使得分类间隔最大化, 其最优化问题如下

$$\begin{aligned} \min_{\omega, b, \xi} & \left\{ \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \right\} \\ \text{s. t.} & \quad y_i (\langle \Phi(\mathbf{x}_i), \omega \rangle + b) \geq 1 - \xi_i \quad \xi_i \geq 0, \forall i = 1, \dots, n \end{aligned} \quad (4)$$

式中: ω 为分类器系数, b 为分类器偏置项, ξ_i 为松弛变量, C 为错分容忍度的权重项, 同时调节分类器的复杂程度。应用对偶原理, 上述原问题等价于其对偶的二次优化问题

$$\begin{aligned} \max_a & \left\{ \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \right\} \\ \text{s. t.} & \quad \sum_{i=1}^n y_i a_i = 0 \\ & \quad 0 \leq a_i \leq C, \forall i = 1, \dots, n \end{aligned} \quad (5)$$

通过式(5), 其对偶形式的解 a_i^* ($i=1, \dots, n$), 故原问题的解为

$$\omega^* = \sum_{i=1}^n a_i^* y_i \Phi(\mathbf{x}_i) \quad (6)$$

由式(6)可以得到广义最优分类面的判别函数为

$$f(\mathbf{x}) = \langle \omega^*, \Phi(\mathbf{x}) \rangle + b^* = \sum_{i=1}^n a_i^* y_i \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}) \rangle + b^* = \sum_{i=1}^n a_i^* y_i K(\mathbf{x}_i, \mathbf{x}) + b^* \quad (7)$$

判别函数 $f(\mathbf{x})$ 不仅可以用来判断样本所属类别, 而且 $f(\mathbf{x})$ 函数的绝对值大小又表明了样本点离分界面的距离远近, 即可信度高低。核方法也为空间信息与光谱信息融合提供了方式。

1.2.2 用于高光谱分类的合成核

定义高光谱像素点 \mathbf{x}_i (为叙述方便, \mathbf{x}_i 既可以表示像素点, 又可以表示像素的特征), $\mathbf{x}_i^w \in \mathbf{R}^d$ 表示对应光谱特征, $\mathbf{x}_i^s \in \mathbf{R}^d$ 表示对应空间特征 (如: 空间均值, 标准差等)。为了有效提高分类精度, 研究者采用同时利用空间信息和光谱信息的策略。下面介绍 3 种经典的空間信息和光谱信息融合的核方法。

(1) 光谱特征和空间特征串联

对于像素点 \mathbf{x}_i , 其特征 $\mathbf{x}_i \equiv \{\mathbf{x}_i^w, \mathbf{x}_i^s\}$ 由其光谱特征与空间特征串联构成。定义核映射 $\Phi(\cdot)$, 将其原始特征从低维空间映射到高维空间的再生核 Hilbert 空间, 可得核函数形式为

$$K_{s,w} \equiv K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \quad (8)$$

这是一种简单的串联方式融合空间和光谱信息。

(2) 直接加和核

像素点 \mathbf{x}_i 其空间特征 \mathbf{x}_i^s 和光谱特征 \mathbf{x}_i^w 也可能映射到不同的 Hilbert 空间, 设 $\varphi_1(\cdot), \varphi_2(\cdot)$ 为对应的非线性映射。定义核映射 $\Phi(\cdot)$, 像素点 \mathbf{x}_i 的映射可表示为

$$\Phi(\mathbf{x}_i) = \{\varphi_1(\mathbf{x}_i^s), \varphi_2(\mathbf{x}_i^w)\}$$

而其对应核函数为

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle = \langle \{\varphi_1(\mathbf{x}_i^s), \varphi_2(\mathbf{x}_i^w)\}, \{\varphi_1(\mathbf{x}_j^s), \varphi_2(\mathbf{x}_j^w)\} \rangle = K_s(\mathbf{x}_i^s, \mathbf{x}_j^s) + K_w(\mathbf{x}_i^w, \mathbf{x}_j^w) \quad (9)$$

可以发现最后核函数结果为空间特征核函数和光谱特征核函数直接加和得到。

(3) 加权加和核

高光谱图像中, 光谱信息和空间信息对分类结果影响不同, 因此需要调节两类信息权重。给定参数 μ 为实数 ($0 < \mu < 1$), 参照方式 2, 可以得到其核函数为

$$K(\mathbf{x}_i, \mathbf{x}_j) = \mu K_s(\mathbf{x}_i^s, \mathbf{x}_j^s) + (1 - \mu) K_w(\mathbf{x}_i^w, \mathbf{x}_j^w) \quad (10)$$

式(10)中以 μ 比重的空间信息参与到最后分类决策中。本文实验中设置 $\mu=0.4$ 以与原文献保持一致。另外还有如把空间特征与光谱特征交叉运算构造核函数的方式, 详见文献[18]。

2 结合分水岭分割的高光谱合成核分类

高光谱图像存在着同物异谱、同谱异物等现象, 合理使用空间信息是改善分类结果的途径之一。空间预处理方式下合成核 SVM 分类方法, 使用固定结窗来提取空间特征, 但是窗口大小却较大程度地影响了空间特征优劣。

空间特征取决于空间近邻的选择。如果可以选出合适的空间近邻, 必然会提高分类精度。本文认为好的空间近邻要满足以下两个要求: (1) 自适应地选择中心待分类像素点空间近邻, 规避窗口大小选择。(2) 尽量选择同类地物, 增强边界区域像素点近邻选择的鲁棒性。

使用分水岭分割解决上述问题, 主要原因在于其过分割的特性, 即使是同一类地物, 也会分成非常细致的小区域(如图2), 而且可以较好刻画边界信息。根据空间平滑特性, 同一区域像素点往往具备相同的类别, 即同一个分割区域的可以认为是互相的空间近邻。同时已经被成功地用于空间后处理方式下的粗分类纠正^[19]。

这里给出算法的形式化描述, 设中心像素为 $\mathbf{x}_0 \in \mathbf{R}^d$, d 表示高光谱波段数, 像素点 \mathbf{x}_0 与其八近邻集合表示为 $\Omega(\mathbf{x}_0) = \{\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_8\}$ 。高光谱图像用 I 表示, 训练集合表示为 $X_{\text{train}} = \{\mathbf{x}_i | \mathbf{x}_i \in \mathbf{R}^d, i=1, 2, \dots, N\}$, N 表示训练集大小, G 表示经过分水岭分割图, G_y 表示分水岭分割图像素点 y 对应分水岭分割图的标识, 分水岭分割选择的空间近邻为 $\Omega_G(\mathbf{x}_0) = \{\mathbf{x} | \mathbf{x} \in G_y, y \in \Omega(\mathbf{x}_0)\}$, 即中心像素点对应的二阶近邻所在的分割标识区域, 保证空间信息与光谱信息区分性较大, 同时减少异类地物混入。通过空间近邻, 就可以计算得到对应的空间统计特征。图3为像素点 \mathbf{x}_0 及对应的八近邻及本文方法得到的分割图近邻, 数字1, 2为分割图标识。

\mathbf{x}_1	\mathbf{x}_2	\mathbf{x}_3	2	1	1	1	1	1
			2	1	1	1	1	1
\mathbf{x}_4	\mathbf{x}_0	\mathbf{x}_5	2	($\mathbf{x}_1, 1$)	($\mathbf{x}_2, 1$)	($\mathbf{x}_3, 1$)	1	1
			2	($\mathbf{x}_4, 1$)	($\mathbf{x}_0, 1$)	($\mathbf{x}_5, 1$)	1	1
			2	($\mathbf{x}_6, 1$)	($\mathbf{x}_7, 1$)	($\mathbf{x}_8, 1$)	1	1
\mathbf{x}_6	\mathbf{x}_7	\mathbf{x}_8	2	2	2	1	1	1
			2	2	2	1	1	1
			2	2	2	1	1	1

图3 像素点 \mathbf{x}_0 八近邻及分水岭分割近邻示意图

Fig. 3 Eight-site and watershed segmentation neighbors for pixel \mathbf{x}_0

下面给出结合分水岭分割的合成核 SVM 高光谱分类(Combing watershed segmentation with composite-kernels svm for hyperspectral classification, WSCSVM)算法步骤。

输入: 高光谱图像 I , 训练集 $X_{\text{train}}, \mathbf{x}_i \in X_{\text{train}}$, 权重调节参数 μ , 其他参数。

输出: X_{test} 分类结果。

(1) 计算高光谱图像 I 梯度值, 使用浸没法得到分割图 G ^[13];

(2) 对每个像素点 $\mathbf{x}_i \in X_{\text{train}}$, 选取空间近邻:

$$\Omega_G(\mathbf{x}_i) = \{\mathbf{x} | \mathbf{x} \in G_y, y \in \Omega(\mathbf{x}_i)\}$$

计算空间统计特征 \mathbf{x}_i^s ;

(3) 使用光谱特征 \mathbf{x}_i^w 与空间特征 \mathbf{x}_i^s 构造合成核 K_{train} , 训练 SVM 分类器;

(4) 对于每个像素点 $\mathbf{x}_i \in X_{\text{test}}$, 选取空间近邻:

$$\Omega_G(\mathbf{x}_i) = \{\mathbf{x} | \mathbf{x} \in G_y, y \in \Omega(\mathbf{x}_i)\}$$

计算空间统计特征 \mathbf{x}_i^s ;

(5) 构造合成核 K_{test} , 给出分类结果。

从 WSCSVM 算法可以看出, 首先通过分割区域选择出自适应空间近邻计算空间特征, 然后使用合

成核 SVM 方式融合空间信息与光谱信息给出分类结果,极具判别性的空间特征有效降低了错分概率。

在计算复杂度上,一次分割便可以快速选择所有像素点空间近邻,效率较高,与传统单样本 SVM 分类器相比,除了核函数的计算不同外,训练和分类过程完全相同,因此速度较快。当传统方法着眼于某一种空间信息辅助分类时,本文结合空间梯度信息来辅助选择空间近邻信息,通过合理利用不同类型空间信息以改善空间特征,从而获得高精度的分类结果。以上讨论中 SVM 采用一对一的分类策略实行。

3 实验与分析

3.1 数据集

本文使用两组高光谱数据集来验证本文算法的有效性,分别是 Indian Pines 数据集和 PU 数据集。Indian Pines 数据集为机载可见红外成像光谱仪(Airborne visible/infrared imaging spectrometer, AVIRIS)采集的农业区高光谱图像^[20],如图 4 所示。图像大小为 145 像素 \times 145 像素,空间分辨率为 20 m/像素,总共有 220 个波段(波长范围 0.4~2.5 μm),除去背景点共 10 366 个样本,去掉 20 个吸水严重的波段,总共 200 个波段高光谱数据。图 4(a,b)分别为对应该高光谱图像的假彩色图像和标记模板。该数据集涉及的地物具有很高的相似性而且样本数据不平衡,对于精确的地物分类具有挑战性,因此被广泛使用于高光谱图像分类算法的性能测试。

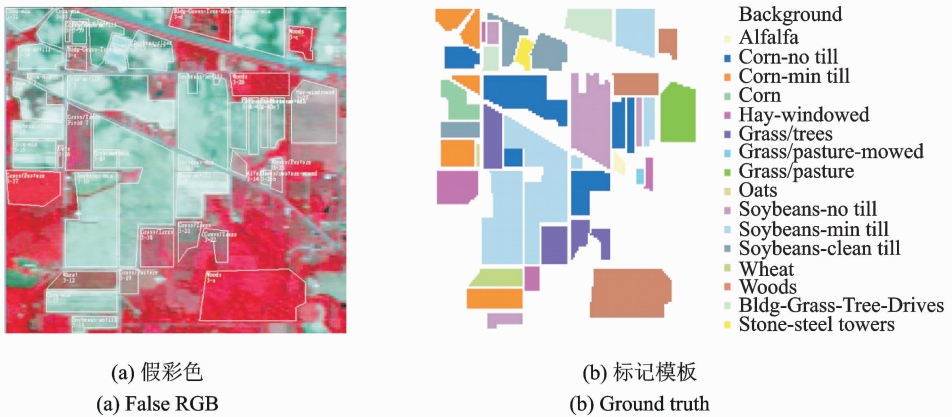


图 4 Indian Pines 数据集

Fig. 4 Indian Pines dataset

PU 数据集为反射光学成像光谱仪(Reflective optics system imaging spectrometer, ROSIS)采集的城区高光谱图像^[21],如图 5 所示。图像大小为 610 像素 \times 340 像素,空间分辨率为 1.3 m/像素,一共包含 115 个光谱波段(波长范围 0.43~0.86 μm),去掉背景点共 42 776 个样本,这里去除其中吸水严重的 12 个波段,其余 103 个波段作为高光谱数据,这个数据集也是经常用来测试高光谱分类方法性能的数据集之一。图 5(a,b)分别为对应的假彩色图和标记模板。

3.2 对比算法与评价指标

为了测试本文所提算法的性能,将本文算法与仅使用光谱特征的分类方法和结合空间特征的分类方法进行对比,其中使用光谱特征的对比方法选择 k -近邻($k\text{NN}$)和 SVM,SVM 分别使用一对一(SVM-1)和一对多(SVM-2)两种策略,结合空间特征的方法,选择基于合成核的方法 SVM- μ (光谱特征和空间均值),以及基于近邻协同的 SVM(NCSVM)^[22]与本文方法进行对比。其中合成核的方法使用加权融合的融合方法,为了对比方便,本文提出的方法也使用加权和方式融合空间信息。对于 $k\text{NN}$ 方法,设置

$k=3$, 合成核中光谱特征核函数计算使用 Polynomial kernel ($d = \{1, \dots, 10\}$), 空间特征使用 RBF kernel, 其余参数与原文献相同。为与其他方法保持一致, NCSVM 方法均不涉及特征降维和空间滤波, 对 Indian Pines 数据集, 近邻大小设置为 $W=5 \times 5$, 对于 PU 数据集近邻大小为 $W=7 \times 7$ 。本文分水岭算法中梯度计算采用 Sumbands 方式。

本文使用的评价指标包括总体正确率 (Over all accuracy, OA)、平均正确率 (Average accuracy, AA)、Kappa 系数^[23]。为避免抽样偏差, 实验中对各实验条件分别进行 10 次独立随机实验取平均值。每次随机抽取一定数量的标记样本作为训练样本, 其余作为测试样本, 然后使用各自算法进行分类。所有算法使用 Matlab 编写, 其中涉及到 SVM 的训练部分使用 Matlab 中自带函数和 LibSVM^[24]。

3.2.1 Indian Pines 数据集

实验中对每类地物随机选取 5% 的样本作为训练样本, 其余作为测试样本, 然后使用各个算法进行分类。如表 1 和图 6 所示, 不同分类方法对应 16 个类别所得到的各类分类结果以及总体结果。

表 1 对 Indian Pines 数据集使用 5% 的训练样本各个算法分类正确率

Tab. 1 Classification accuracy for Indian Pines dataset using 5% training samples per class

序号	类别	训练样本	测试样本	k NN	SVM-1	SVM-2	SVM- μ	NCSVM	本文方法
1	Alfalfa	3	51	36.86	63.33	59.80	88.24	79.22	85.88
2	Corn-no till	72	1 362	65.07	79.32	79.44	94.02	90.40	96.57
3	Corn-min till	42	792	50.48	72.35	71.45	94.75	89.04	96.44
4	Corn	12	222	29.19	50.72	52.57	88.06	78.47	91.67
5	Grass-pasture	25	472	81.59	88.92	88.37	91.24	93.73	94.09
6	Grass-trees	38	709	93.71	94.26	94.78	97.94	99.17	99.15
7	Grass-pasture-mowed	3	23	70.87	81.74	82.17	96.09	92.61	93.91
8	Hay-windrowed	25	464	97.41	97.31	98.17	99.09	99.98	99.99
9	Oats	3	17	55.88	67.06	74.12	78.82	81.76	96.47
10	Soybean-no till	49	919	69.47	74.29	75.22	89.53	86.97	91.45
11	Soybean-min till	124	2 344	70.39	80.89	80.58	94.76	94.51	96.30
12	Soybean-clean	31	583	36.83	73.72	76.83	90.91	92.73	92.18
13	Wheat	11	201	97.01	98.16	98.86	98.71	99.20	98.36
14	Woods	65	1 229	94.96	94.91	95.19	97.05	98.73	98.89
15	Building-grass-trees-drives	19	361	23.85	50.78	53.38	85.82	72.63	88.92
16	Stone-steel-towers	5	90	86.00	89.44	87.56	99.22	96.44	95.67
总体正确率(OA)				70.39	81.35	81.70	94.08	92.62	95.85
平均正确率(AA)				66.22	78.57	79.28	92.78	90.35	94.74
k 系数				66.15	78.74	79.15	93.26	91.56	95.27

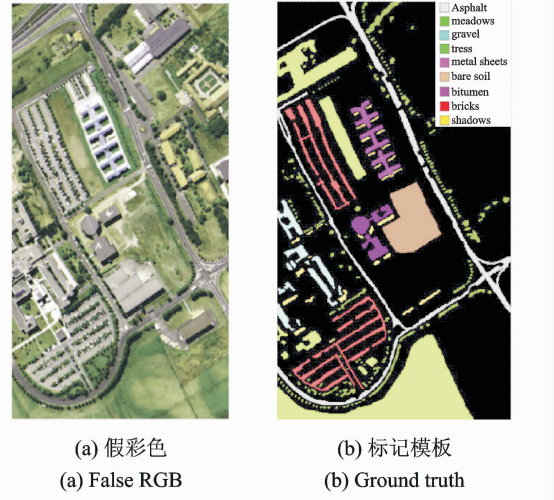


图 5 PU 数据集

Fig. 5 PU dataset

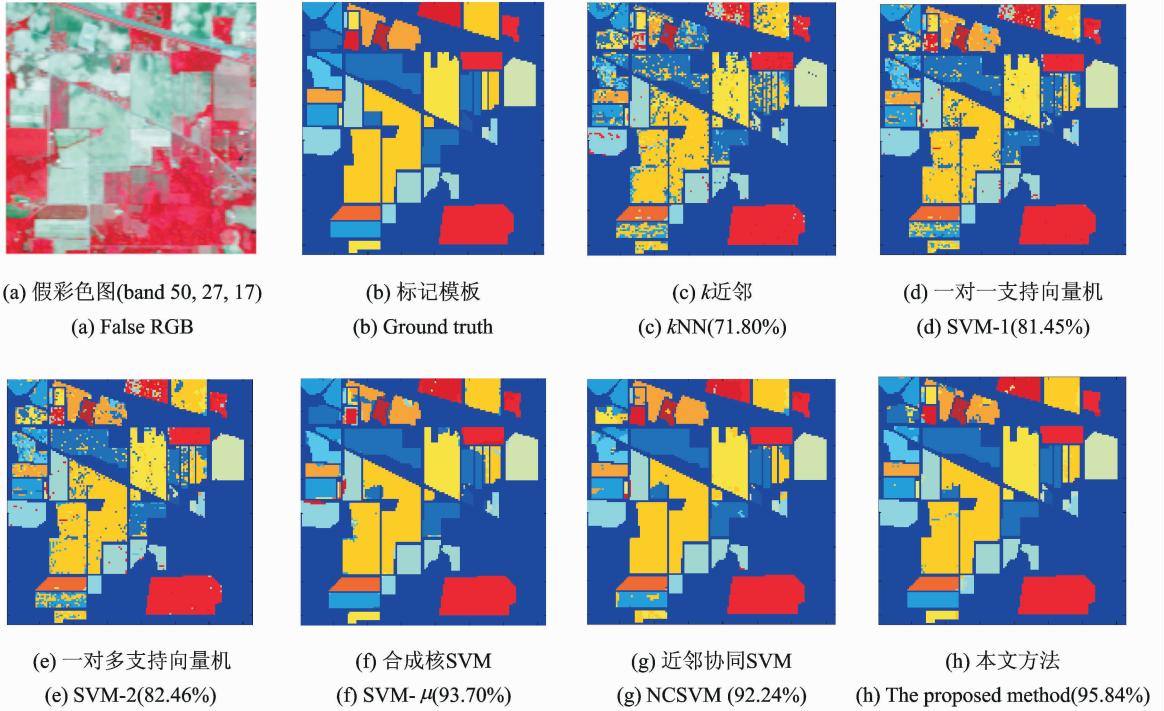


图6 Indian Pines 数据集:使用5%的训练样本各个算法得到的分类图及对应正确率

Fig. 6 Classification maps and overall accuracy (OA) for the Indian Pines dataset using 5% training samples per class

通过表1可以发现在大多数类别中单纯地使用光谱特征进行分类,如 k NN和SVM,其分类正确率均较低,如第1,4,15类,在图6(c,d)中可以很明显的观察到中间蓝色区域Corn-no till类被较大程度错分,总体分类结果较差。而SVM- μ ,NCSVM和本文方法分类的正确率在对应的类别上均有明显的提高,说明除了光谱信息外,地物分布的空间信息在分类中扮演的重要作用。将经典的SVM和SVM- μ 分类结果比较可以发现,如第1,10类,相对于经典SVM,使用SVM- μ 的方法提高了约30%和15%的精度,这也可以看出空间均值这一特征对分类性能的影响,以及空间信息在高光谱图像分类中的重要作用。

NCSVM也受制于窗口大小的选择,当所分类区域较大时候,NCSVM能够比较好地给出分类结果,但是当分类地物较小时很容易把其他地物也包括进去,如表1中类别1,9。从表1还可以发现经典的SVM分类结果稍好的类别,如第5,6类,NCSVM结果同样优异;但是对于1,4类,因为经典SVM分类精度低,即便考虑到空间信息,仍然不能达到令人满意的精度。

本文提出的方法是基于合成核SVM的改进,因此保留了其优点,在SVM- μ 基础上稳步提高,如第1,2类,NCSVM受制于窗口大小选择和经典SVM粗分类结果,明显差于本文算法,如第3类。表1中黑色数字表示本文提出的方法在多个类别取得最好的单分类结果。但在边界区域可以通过图7(a)上方红框明显地看出,本文方法对中心黄色区域Soybean-no till类取得了最好的分类结果,而图7(b)中SVM- μ 方法因为窗口大小选择问题导致包含过多异类地物,最终混杂的空间信息反而影响了分类结果,图7(c)中NCSVM方法则受制于粗分类结果以及窗口大小的选择,几乎全部被错分。在图7(a)右方红框和左方红框同样证明了本文算法在边界区域的有效性。

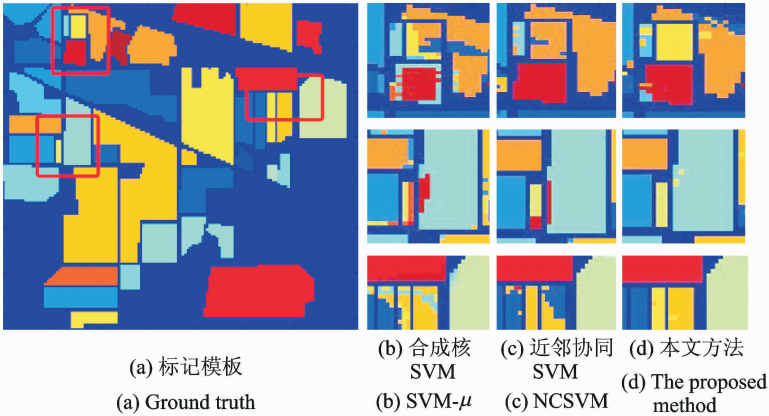


图 7 Indian Pines 数据集细节对比图

Fig. 7 Detailed comparison for the Indian Pines dataset

3.2.2 PU 数据集

表 2 和图 8 给出了 PU 数据集的实验结果,可以发现类似的结论。从表 2 可以看出单纯的光谱特征分类精度受限于同物异谱、同谱异物问题而不能令人满意,如第 3,6 类。 k NN 分类器相较于经典 SVM 分类精度更低。而相对于结合空间信息的后 3 种方法,不同类别的分类精度均有较大幅度提高,也可以通过图 8(b~h)观察对比得到。

SVM- μ 分类算法在多数类别中都保持了较优异的分类结果,即使是分类精度最低的第 6 类,也有 84% 左右的分类精度,相比于经典 SVM 分类以及 NCSVM 分类,结果都更稳定。

NCSVM 因其方法本身特性受制于粗分类结果,如第 3,6 类,其分类精度明显差于本文方法,也可以看出当传统 SVM 分类结果较好时,NCSVM 结合空间信息给出了更好的分类结果,如表 2 中第 1,2 类,可以通过图 8(g)中黄色区域 Bare soil 类对比发现。

表 2 对 PU 数据集使用 1% 的训练样本各个算法分类正确率

Tab. 2 Classification accuracy for PU dataset using 1% training samples per class

序号	类别	训练样本	测试样本	k NN	SVM-1	SVM-2	SVM- μ	NCSVM	本文方法	%
1	Asphalt	67	6564	74.64	83.44	81.99	95.24	96.35	96.02	
2	Meadows	187	18462	96.42	96.14	95.67	98.00	99.87	98.80	
3	Gravel	21	2078	48.40	63.59	63.96	86.59	71.04	88.77	
4	Trees	31	3033	72.93	87.53	88.65	91.55	92.75	91.05	
5	Painted metal sheets	14	1331	98.58	98.51	98.10	99.66	99.90	99.89	
6	Bare soil	51	4978	34.97	63.45	65.46	84.03	71.18	89.25	
7	Bitumen	14	1316	69.00	72.77	72.86	94.00	93.86	96.65	
8	Self-blocking bricks	37	3645	75.40	78.55	78.24	87.78	97.00	90.37	
9	Shadows	10	937	83.47	96.72	78.69	93.43	97.28	92.06	
总体正确率(OA)				78.90	85.96	85.43	93.85	93.54	95.29	
平均正确率(AA)				72.65	82.30	80.40	92.25	91.04	93.65	
k 系数				71.08	81.13	80.46	91.81	91.30	93.73	

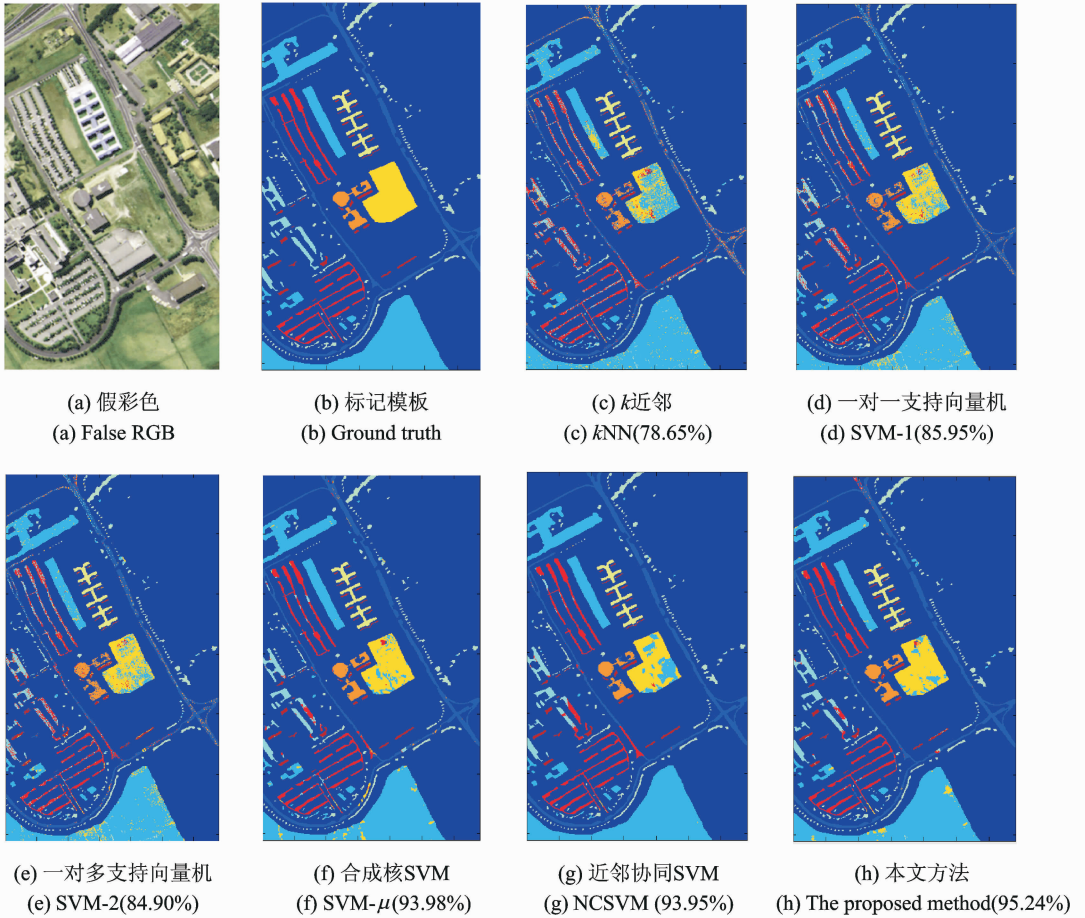


图 8 PU数据集:使用1%的训练样本各个算法得到的分类图及对应正确率

Fig. 8 Classification maps and overall accuracy(OA) for the PU dataset using 1% training samples per class

本文方法在多个类别上都取得了最优结果,相对于SVM- μ 分类方法,在继承其稳定性的基础上提高了分类精度,如表2中第3,6,7类,也不会存在像NCSVM受到粗分类结果影响的问题。图9给出了SVM- μ ,NCSVM和本文方法细节对比图,从图9(b)中可以发现SVM- μ 方法对深红色上方青色区域Gravel类全部错分,主要因为SVM- μ 固定窗口选择的空间信息混入了深红色像素点异类地物。而图9(c)中NCSVM方法受制于粗分类的结果,使得青色区域部分地被错分为Bricks类别。从图9(d)中可以发现本文方法在对深红色区域上方Gravel类区域给出了较好的分类结果,证明了算法的有效性,同时左上方青色区域被错分像素点也较少,优于其他两种方法结果。




图 9 PU数据集细节对比图

Fig. 9 Detailed comparison for the PU dataset

4 结束语

高光谱分类中单纯使用光谱信息并不能解决其面临的同物异谱、同谱异物等问题,研究发现,通过结合空间信息,可以极大地减小高光谱图像的错分概率,因此传统空间预处理方式下通过固定窗提取空间特征辅助分类,但其特征的优劣较大程度受固定窗口大小影响,难以给出一个合适的选择。为有效挖掘和利用空间信息,本文提出的结合分水岭分割区域的近邻选择,通过自适应的分割区域选出紧致而具判别性空间近邻,然后通过合成核 SVM 方法把优质的空间特征融入到原光谱分类中,保证了可靠的分类判断。相比已有的方法,本文方法实现了少量样本下的快速高精度分类。如何提取到更具判别性的空间特征,如何合理有效地利用不同空间信息等是值得继续研究的方向。

参考文献:

- [1] Shaw G, Manolakis D. Signal processing for hyperspectral image exploitation[J]. *Signal Processing Magazine*, 2002,19(1): 12-16.
- [2] 黄敏,朱晓,朱启兵,等.基于主动轮廓模型的玉米种子高光谱图像分类[J].*数据采集与处理*,2013,28(3):289-293.
Huang Min, Zhu Xiao, Zhu Qibing, et al. Hyperspectral image classification of maize seeds based on active contour model [J]. *Journal of Data Acquisition and Processing*, 2013,28(3):289-293.
- [3] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013,101(3):652-675.
- [4] Hughes G. On the mean accuracy of statistical pattern recognizers[J]. *IEEE Transactions on Information Theory*, 1968,14 (1):55-63.
- [5] 张学工.关于统计学习理论与支持向量机[J].*自动化学报*,2000,26(1):32-42.
Zhang Xuegong. Introduction to statistical learning theory and support vector machines[J]. *Acta Automatica Sinica*, 2000, 26(1):32-42.
- [6] Fauvel M, Benediktsson J A, Chanussot J, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008,46(11):3804-3814.
- [7] Gurram P, Heesung K. Contextual SVM using Hilbert space embedding for hyperspectral classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013,10(5):1031-1035.
- [8] Chen Yi, Nasser M, Nasrabadi, et al. Classification for hyperspectral imagery based on sparse representation[C]//*IEEE Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. Reykjavik:[s. n.], 2010:1-4.
- [9] Chen Yi, Nasser M, Nasrabadi, et al. Hyperspectral image classification using dictionary-based sparse representation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2011,49(10):3973-3985.
- [10] Liu Jianjun, Wu Zebin, Sun Le, et al. Hyperspectral image classification using kernel sparse representation and semilocal spatial graph regularization[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014,11(8):1320-1324.
- [11] Li Cheng-Hsuan, Kuo Bor-Chen, Lin Chin-Teng. A spatial-contextual support vector machine for remotely sensed image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012,50(3):784-799.
- [12] Tarabalka Y, Fauvel M, Chanussot J, et al. SVM and MRF-based method for accurate classification of hyperspectral images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2010:736-740.
- [13] Vincent L, Soille P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations[J]. *IEEE Trans Pattern Anal Mach Intell*, 1991,13(6):583-598.
- [14] Tarabalka Y, Chanussot J, Benediktsson J A. Segmentation and classification of hyperspectral images using watershed transformation[J]. *Pattern Recognition*, 2010,43(7):2367-2379.
- [15] Tarabalka Y, Chanussot J, Benediktsson J A. Segmentation and classification of hyperspectral images using minimum spanning forest grown from automatically selected markers[J]. *Systems Man and Cybernetics Part B: Cybernetics IEEE Transactions on*, 2010,40(5):1267-1279.

- [16] Tarabalka Y, Tilton J C, Benediktsson J A, et al. A marker-based approach for the automated selection of a single segmentation from a hierarchical set of image segmentations[J]. IEEE J Sel Top Appl Earth Observat Remote Sens, 2012,5(1): 262-272.
- [17] Tarabalka Y, Chanussot J, Benediktsson J A, et al. Segmentation and classification of hyperspectral data using watershed [C]//Proc IGARSS'08. Boston, USA: IEEE, 2008:652-655.
- [18] Camps-Valls G, Gomez-Chova L, Munoz-Mari J, et al. Composite kernels for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2006,3(1):93-97.
- [19] Mostafa B, Hassan G. Hyperspectral image classification based on spatial graph kernel[C]//IEEE the 22nd Iranian Conference on Electrical Engineering. Tehran: IEEE, 2014:1811-1816.
- [20] Tadjudin S, Landgrebe D A. Covariance estimation with limited training samples[J]. IEEE Transactions on Geoscience and Remote Sensing, 1999,37(4):2113-2118.
- [21] Tarabalka Y, Tilton J C, Benediktsson J A. Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009,47(8):2973-2987.
- [22] 倪鼎,马洪兵. 基于近邻协同的高光谱图像谱-空联合分类[J]. 自动化学报, 2015,41(2):273-284.
Ni Ding, Ma Hongbing. Spectral-spatial classification of hyperspectral images based on neighborhood collaboration[J]. Acta Automatica Sinica, 2015,41(2):273-284.
- [23] Richards J A, Jia Xiuping. Remote sensing digital image analysis: An introduction[M]. New York: Springer-Verlag, 1986: 47-54.
- [24] Chang Chih-Chung, Lin Chih-Jen. LIBSVM-A library for support vector machines[EB/OL]. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2014-04-01/2014-10-27.

作者简介:



赵振凯(1990-),男,硕士研究生,研究方向:高光谱分类, E-mail: zzkgo @ qq.com。



杨明(1964-),男,教授,研究方向:机器学习,模式识别, E-mail: myang@nynu.edu.cn。

(编辑:张彤)

